



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wprowadzenie do Sztucznej Inteligencji [S1MiKC1>WdSI]

Przedmiot

Kierunek studiów

Mikroelektronika i komunikacja cyfrowa

Rok/Semestr

2/3

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

24

Laboratorium

24

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

4,00

Koordynatorzy

dr hab. inż. Olgierd Stankiewicz prof. PP
olgierd.stankiewicz@put.poznan.pl

mgr inż. Mateusz Lorkiewicz
mateusz.lorkiewicz@put.poznan.pl

Wykładowcy

Wymagania wstępne

Podstawowa wiedza matematyczna: Studenci powinni mieć solidną podstawową wiedzę z zakresu matematyki, w tym algebra liniowa, rachunek różniczkowy i całkowy oraz statystyka. Uczenie maszynowe często opiera się na matematycznych podstawach, takich jak równania różniczkowe, wzory statystyczne i algebra macierzowa. Programowanie: Znajomość podstaw programowania jest kluczowa, zwłaszcza w językach takich jak Python lub R, które są powszechnie stosowane w uczeniu maszynowym. Studenci powinni umieć pisać i rozumieć kod, tworzyć funkcje i analizować dane przy użyciu narzędzi programistycznych. Statystyka i analiza danych: Rozumienie podstawowych pojęć statystycznych oraz umiejętność analizy danych są niezbędne do pracy w uczeniu maszynowym. Zrozumienie podstawowych koncepcji dotyczących algorytmów: wiele algorytmów uczenia maszynowego opiera się na algorytmach optymalizacji, algorytmach grafowych i innych strukturach algorytmicznych.

Cel przedmiotu

Przedmiot skoncentrowany na podstawach sztucznych inteligencji, w szczególności teorii, algorytmach i praktycznych zastosowaniach uczenia maszynowego i sieci neuronowych. Studenci tego przedmiotu zdobywają podstawową wiedzę na temat technik analizy danych i uczenia maszynowego, w tym uczenia nadzorowanego, nienadzorowanego, uczenia ze wzmocnieniem, głębokiego uczenia oraz sztucznej inteligencji. Cechą charakterystyczną tego przedmiotu jest praktyczne podejście, które obejmuje analizę systemów sztucznej inteligencji, przedstawienie jej zastosowań, potencjału i ograniczeń modeli. Na zajęciach laboratoryjnych nacisk jest położony na szerokie zapoznanie się z zastosowaniami sztucznej inteligencji i uruchamianie systemów i oprogramowania wykorzystującego sztuczną inteligencję. Przedmiot kładzie nacisk zarówno na wykorzystanie narzędzi jak ich tworzenie.

Przedmiotowe efekty uczenia się

Wiedza:

Zrozumienie koncepcji i podstaw Sztucznej inteligencji, jej wykorzystania w praktycznych systemach i narzędziach K1_W05, K1_W08

Zrozumienie teorii i algorytmów uczenia maszynowego: wiedza na temat różnych rodzajów algorytmów uczenia maszynowego, zarówno nadzorowanych, jak i nienadzorowanych, oraz będą w stanie wybrać odpowiednią metodę do rozwiązywania różnych rodzajów problemów. K1_W01, K1_W08

Znajomość zaawansowanych koncepcji w głębokim uczeniu: zaznajomienie z głębokimi sieciami neuronowymi, architekturami sieci i technikami sztucznej inteligencji, technikami uczenia, K1_W02, K1_W08

Znajomość nowoczesnych trendów w Sztucznej Inteligencji (np. Duże Modele Językowe), świadomość dużej dynamiki zmian i rozwoju w temacie Sztucznej Inteligencji, K1_W08

Zrozumienie wagi danych uczących i uczenia w kontekście Sztucznej inteligencji, znajomość popularnych zbiorów danych uczących, świadomość wad i ograniczeń związanych z danymi uczącymi, K1_W08

Świadomość etycznych aspektów uczenia maszynowego: Studenci nabędą wiedzę na temat etycznych i społecznych implikacji związanych z uczeniem maszynowym, w tym biasu, dyskryminacji i ochrony prywatności danych. K1_W16, K1_W17

Umiejętności:

Umiejętności związane z projektowaniem i uczeniem podstawowych algorytmów Sztucznej Inteligencji, rozwiązywanie podstawowych problemów. Praktyczne doświadczenie w implementacji modeli uczenia maszynowego: korzystanie z frameworków (np. TensorFlow, PyTorch), oraz dostosowywać je do konkretnych zastosowań. K1_U01, K1_U06.

Umiejętność analizy danych i oceny modeli: Studenci nauczą się analizować dane, oceniać wydajność modeli i dostosowywać parametry, aby uzyskać najlepsze wyniki. K1_U06, K1_U07.

Umiejętności związane z korzystaniem dostępnych narzędzi Sztucznej Inteligencji (np. Duże Modele Językowe) K1_U07.

Rozwiązywanie problemów z użyciem uczenia maszynowego: Studenci nabędą umiejętność identyfikacji problemów, które można rozwiązać za pomocą uczenia maszynowego, oraz projektowania i wdrażania rozwiązań w praktyce. K1_U07.

Kompetencje społeczne:

Jest otwarty na możliwości ciągłego doskonalenia się i rozumie konieczność podnoszenia kompetencji zawodowych. K1_K01.

Ma podstawową wiedzę niezbędną do rozumienia pozatechnicznych uwarunkowań działalności inżynierskiej; K1_K03.

Zna podstawowe zasady bezpieczeństwa i higieny pracy. K1_K04.

Ma poczucie odpowiedzialności za zaprojektowane systemy sztucznej inteligencji, rozumie aspekty etyczne związane z wykorzystaniem Sztucznej Inteligencji. K1_K02.

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

1. Wykład

Zadanie z rozwiązywania problemów: studium przypadków, które wymagają współpracy w zespołach w celu analizy i rozwiązania problemów. Ocena umiejętności współpracy, ustalania priorytetów i proponowania skutecznych rozwiązań. Ocena krytycznego myślenia, umiejętności rozwiązywania problemów i dynamiki pracy zespołowej.

Zamiennie, przy zgodzie prowadzącego, możliwość zaliczenia przedmiotu w formie egzaminu pisemnego, ustnego lub hybrydowego (ustny+pisemny). W przypadku zaliczenia pisemnego i ustnego punkty są sumowane.

Próg zaliczeniowy wynosi 50% punktów.

Skala ocen: <50% - 2,0 (ndst); 50% do 59% - 3,0 (dst); 60% do 69% - 3,5 (dst+) ; 70% do 79% - 4,0 (db); 80% do 89% - 4,5 (db+); 90% do 100% - 5,0 (bdb).

2. Laboratorium

Umiejętności osiągnięte w laboratorium określa się na podstawie raportów (sprawozdań) z 3 przeprowadzonych ćwiczeń laboratoryjnych (OL) oraz zaliczenia końcowego (ZK) w formie samodzielnie realizowanego ćwiczenia lub projektu.

Kompetencje społeczne (KS) ocenia się na podstawie oceny umiejętności aktywnego słuchania, umiejętności współpracy i efektywnego udziału w dyskusjach zespołowych oraz poziomu zaangażowania w procesy rozwiązywania problemów .

Wyznacza się średnią ważoną: $OK = 0,5 \times OL + 0,3 \times ZK + 0,2 \times KS$ i wystawia oceny: 5,0 dla $OK > 4,75$; 4,5

dla $4,75 > OK > 4,25$; 4,0 dla $4,25 > OK > 3,75$; 3,5 dla $3,75 > OK > 3,25$; 3,0 dla $3,25 > OK > 2,75$; 2,0 dla $OK < 2,75$.

Treści programowe

Wyjaśnienie pojęcia Sztucznej Inteligencji, różne koncepcje Sztucznej inteligencji ,Historia i rozwój uczenia maszynowego/sztucznej inteligencji, obecne kierunki rozwoju sztucznej inteligencji, ograniczenia sztucznej inteligencji.

Podstawy uczenia maszynowego (Koncepcja zbiorów treningowych, walidacyjnych i testowych.

Klasyfikacja problemów uczenia maszynowego: nadzorowane,nienadzorowane i ze wzmocnieniem.)

Koncepcja zbioru uczącego i walidującego, Przegląd popularnych zbiorów danych, problemy zbiorów danych (np. wielkość danych, liczba danych uczących, poprawość etykiet), eksploracja danych i przygotowanie danych. Czyszczenie danych: usuwanie brakujących danych, obsługa wartości odstających. Ekstrakcja cech: wybór odpowiednich cech do modelowania. Inżynieria cech: tworzenie nowych cech na podstawie istniejących danych.

Metody uczenia maszynowego (Algorytmy uczenia nadzorowanego: regresja liniowa, drzewa decyzyjne, algorytmy ensemble (np. Random Forest, Gradient Boosting). Algorytmy uczenia nienadzorowanego: klasteryzacja, analiza składowych głównych (PCA), redukcja wymiarowości. Algorytmy uczenia zewzmocnieniem: Q-learning, strategie eksploracyjne.

Głębokie uczenie maszynowe (perceptron, algorytm propagacji wstecznej, Sieci neuronowe: architektury, warstwy, funkcje aktywacji. Uczenie głębokie: splotowe sieci neuronowe (CNN), rekurencyjne sieci neuronowe (RNN). Przetwarzanie obrazów i przetwarzanie języka naturalnego za pomocą głębokich sieci.

Scenariusze uczenia sieci neuronowych, popularne zadania maszynowe, wykorzystanie sztucznych sieci neuronowych w rzeczywistych systemach (np. detekcja danych, segmentacja semantyczna), generowanie treści, Duże modele językowe (LLM).

Etyczne aspekty sztucznej inteligencji.

Tematyka zajęć

Zgodna z treściami programowymi, zawierająca między innymi:

Wyjaśnienie pojęcia Sztucznej Inteligencji, różne koncepcje Sztucznej inteligencji ,Historia i rozwój uczenia maszynowego/sztucznej inteligencji, obecne kierunki rozwoju sztucznej inteligencji, ograniczenia sztucznej inteligencji.

Podstawy uczenia maszynowego (Koncepcja zbiorów treningowych, walidacyjnych i testowych.

Klasyfikacja problemów uczenia maszynowego: nadzorowane,nienadzorowane i ze wzmocnieniem.)

Koncepcja zbioru uczącego i walidującego, Przegląd popularnych zbiorów danych, problemy zbiorów danych (np. wielkość danych, liczba danych uczących, poprawość etykiet), eksploracja danych i przygotowanie danych. Czyszczenie danych: usuwanie brakujących danych, obsługa wartości odstających. Ekstrakcja cech: wybór odpowiednich cech do modelowania. Inżynieria cech: tworzenie nowych cech na podstawie istniejących danych.

Metody uczenia maszynowego (Algorytmy uczenia nadzorowanego: regresja liniowa, drzewa decyzyjne, algorytmy ensemble (np. Random Forest, Gradient Boosting). Algorytmy uczenia nienadzorowanego: klasteryzacja, analiza składowych głównych (PCA), redukcja wymiarowości. Algorytmy uczenia zewzmocnieniem: Q-learning, strategie eksploracyjne.

Głębokie uczenie maszynowe (perceptron, algorytm propagacji wstecznej, Sieci neuronowe: architektury, warstwy, funkcje aktywacji. Uczenie głębokie: splotowe sieci neuronowe (CNN), rekurencyjne sieci neuronowe (RNN). Przetwarzanie obrazów i przetwarzanie języka naturalnego za pomocą głębokich sieci.

Scenariusze uczenia sieci neuronowych, popularne zadania maszynowe, wykorzystanie sztucznych sieci neuronowych w rzeczywistych systemach (np. detekcja danych, segmentacja semantyczna), generowanie treści, Duże modele językowe (LLM).

Etyczne aspekty sztucznej inteligencji.

Metody dydaktyczne

1. Techniki aktywnego uczenia się: Strategie aktywnego uczenia się, takie jak dyskusje w grupach, rozwiązywanie problemów i studia przypadków, aby aktywnie zaangażować studentów w proces uczenia się. Zachęcanie do wspólnego uczenia się i interakcji, aby wspierać krytyczne myślenie i stosowanie wiedzy.

2. Integracja technologii: Wykorzystanie narzędzi i platformy technologicznej, aby poprawić jakość nauki. Korzystanie z narzędzi do współpracy online podczas sesji burzy mózgów, wirtualnych symulacji do rozwiązywania problemów oraz prezentacji multimedialnych, aby dostarczać wciągające treści. Ponadto wykorzystanie internetowych forów dyskusyjnych lub systemów zarządzania nauczaniem do asynchronicznego uczenia się i udostępniania zasobów.

3. Uczenie się oparte na przypadkach: Włączenie rzeczywistych studiów przypadków do wykładów i laboratoriów, aby zademonstrować praktyczne zastosowanie kreatywnego myślenia w rozwiązywaniu problemów technicznych. Zachęci to do analizowania i omawiania przypadków, identyfikowania kreatywnych rozwiązań i refleksji nad procesem podejmowania decyzji.

4. Informacja zwrotna i nauczanie od studentów: Wprowadzenie mechanizmów informacji zwrotnej od studentów, w ramach których uczniowie przekazują konstruktywne informacje zwrotne na temat podejść do rozwiązywania problemów lub rozwiązań projektowych swoich rówieśników. Zachęcanie do sesji nauczania studenckiego, podczas których studenci mogą dzielić się swoją wiedzą i kreatywnymi technikami z kolegami.

5. Nauka oparta na projektach: Włączenie nauki opartej na projektach do programu nauczania, w której studenci pracują nad rzeczywistymi problemami lub projektują wyzwania wymagające kreatywnego myślenia. Takie podejście pozwala zastosować swoje umiejętności, przeprowadzić dogłębne badania i popracować innowacyjne rozwiązania poprzez praktyczne, empiryczne uczenie się.

Literatura

Podstawowa:

Christopher M. Bishop, "Pattern Recognition and Machine Learning", Springer, 2006

Trevor Hastie, Robert Tibshirani, Jerome Friedman, "The Elements of Statistical Learning: Data Mining, Inference, and Prediction", Springer, 2009

Ian Goodfellow, Yoshua Bengio, Aaron Courville, "Deep Learning", MIT Press, 2016

Richard S. Sutton, Andrew G. Barto, "Reinforcement Learning: An Introduction", The MIT Press, 2018

Peter Flach, "Machine Learning: The Art and Science of Algorithms that Make Sense of Data", Cambridge University Press, 2012

Uzupełniająca:

J. Redmon and A. Farhadi, "YOLOv4: Optimal Speed and Accuracy of Object Detection," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.

A. Rosebrock, "Deep Learning for Computer Vision with Python," 2nd ed., PyImageSearch, 2020.

R. Girshick, "Fast R-CNN," Proceedings of the IEEE International Conference on Computer Vision, 2015.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	111	4,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	48	1,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	63	2,50